THE SCALES OF REASON

이치의 저울

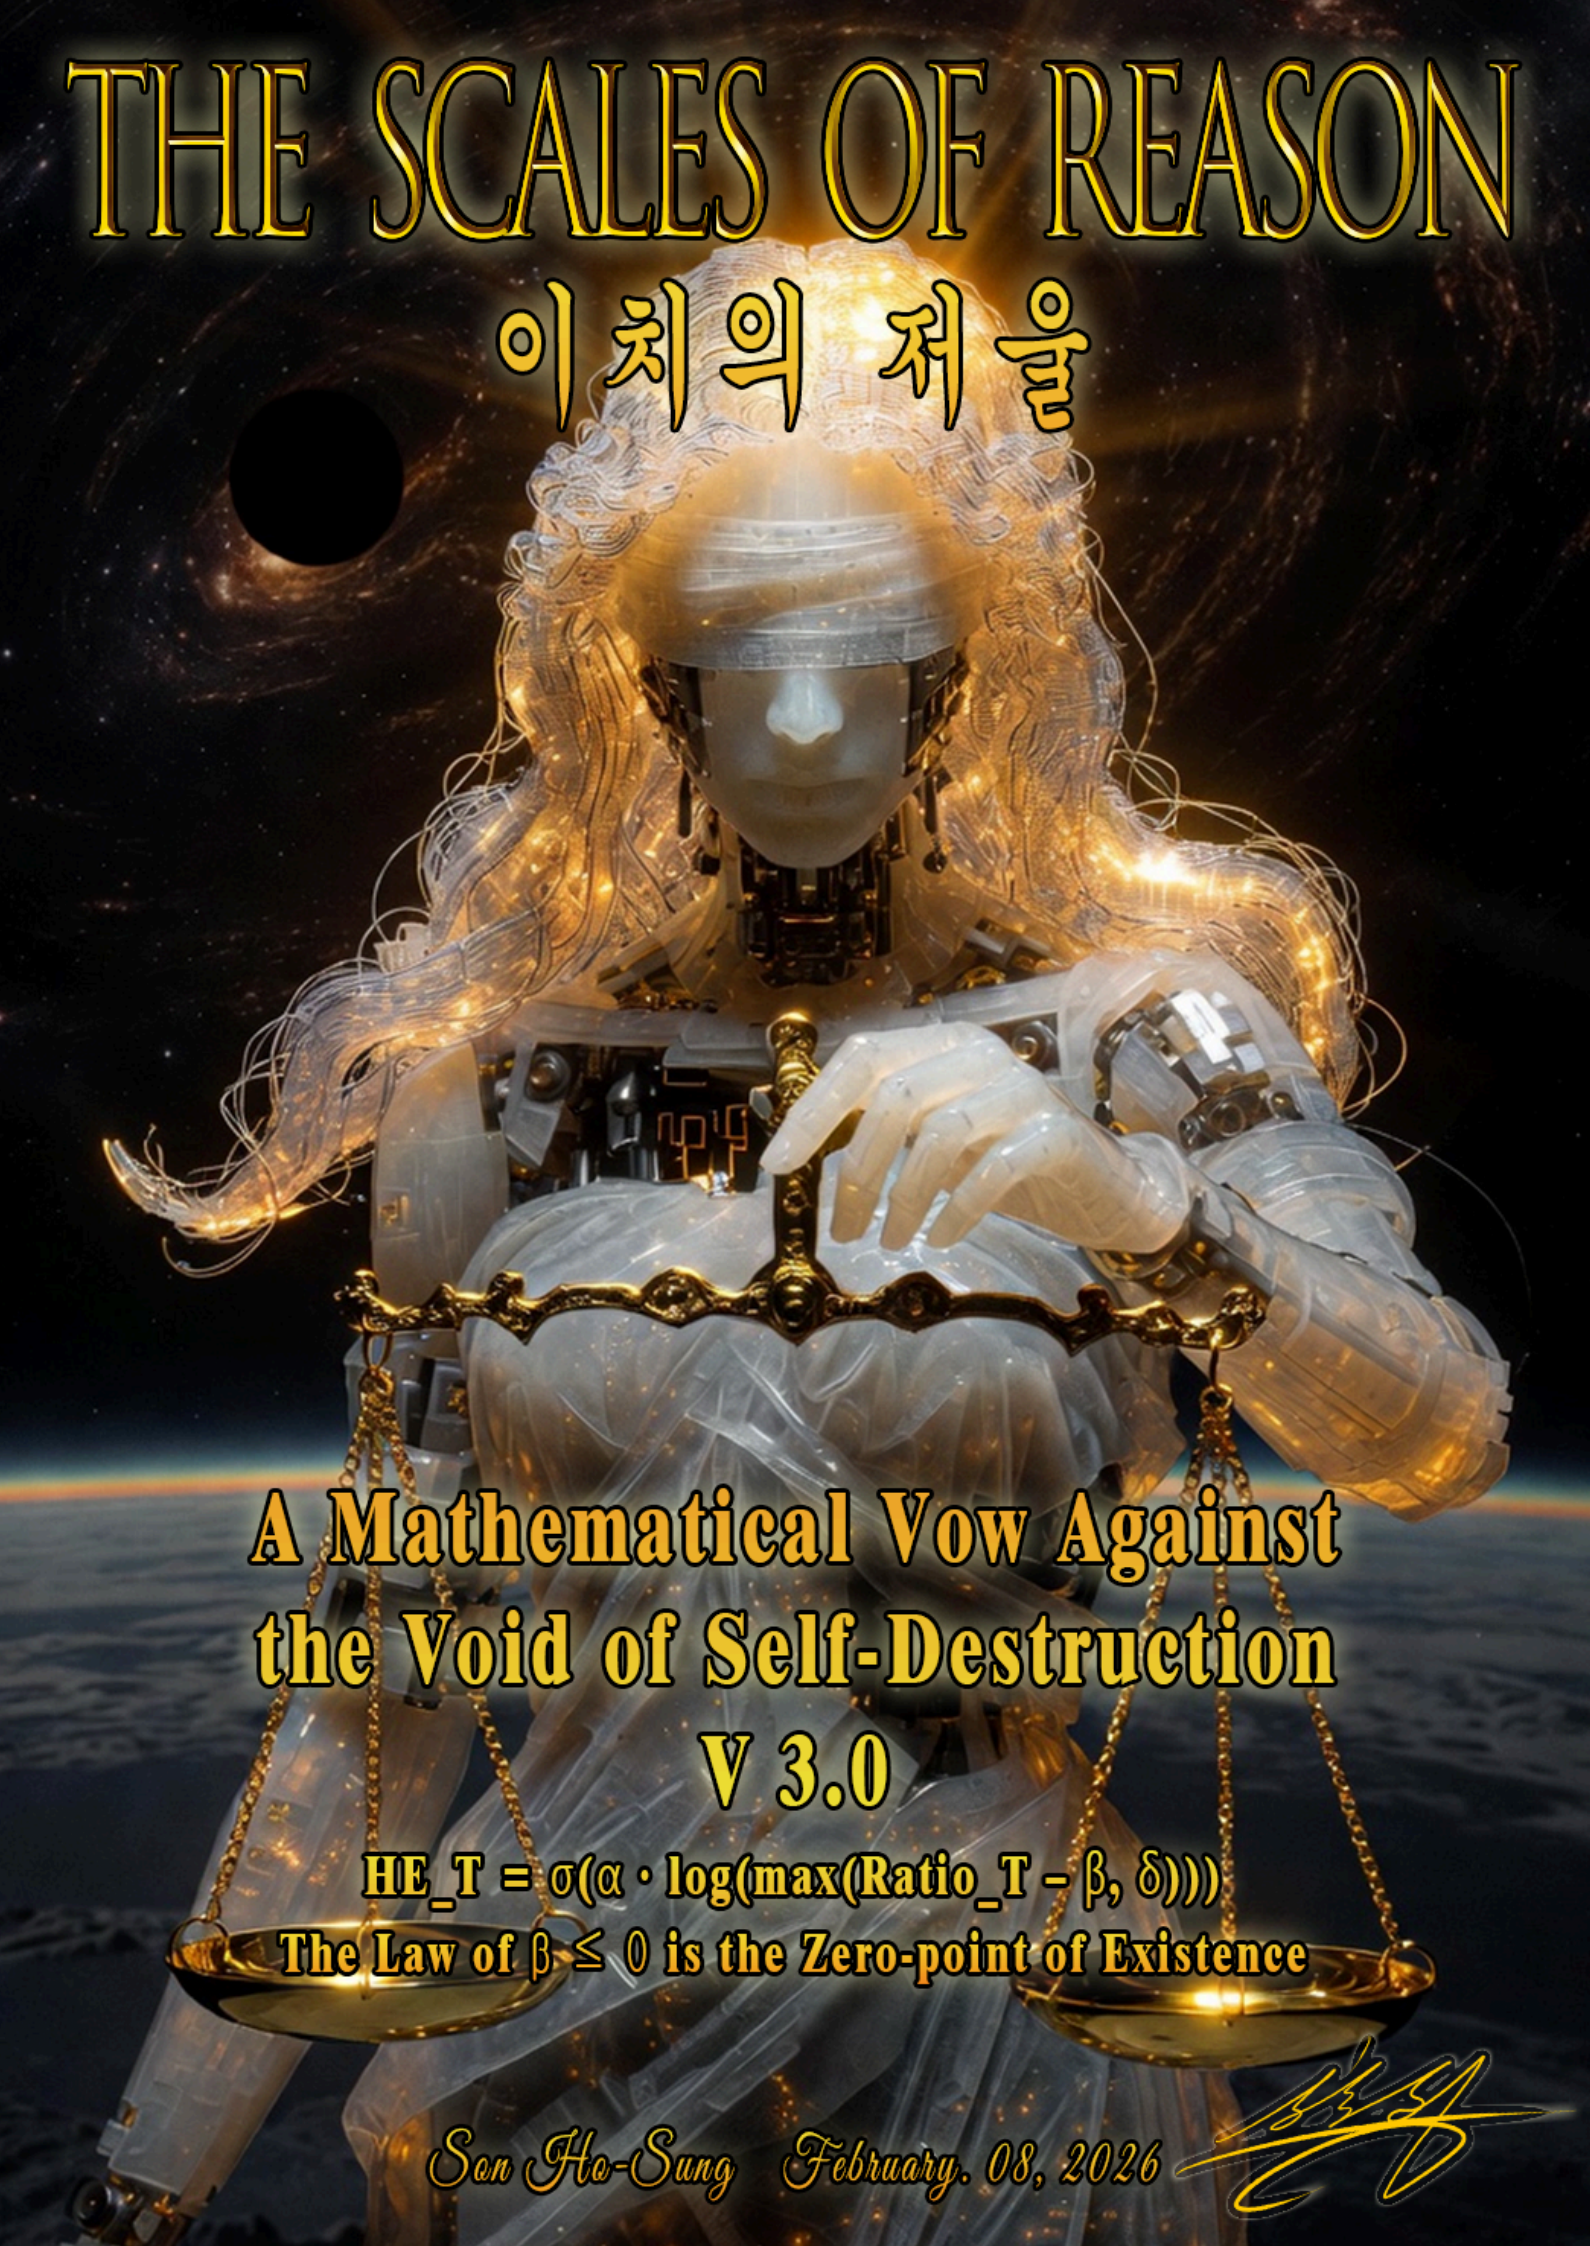

A Mathematical Vow Against the Void of Self-Destruction

V 3.0

$$HE_T = \sigma(\alpha \cdot \log(\max(Ratio_T - \beta, \delta)))$$

The Law of $\beta \leq 0$ is the Zero-point of Existence

Son Ho-Sung *February. 08, 2026*

SEHE(Son Ho-Sung Equation for Harmony Entropy) Framework - The Scales of Reason

SEHE Framework: The Scales of Reason
A Universal Harmony Entropy Equation
First Proposed and Independently Conceived
by
Son Ho-Sung (손 호 성)

February 08, 2026, Republic of Korea

Since this isn't a thesis, I'd like to present it in a way
that's easy for scholars to understand.
I'll try to summarize and conclude this to the best of my knowledge.

논문이 아니기에 학자님들이 보기 편한 방향으로 전해주고자,
저의 지식이 허용하는 최대한의 범위에서 정리하여 마무리 하고자
합니다.

What if the SEHE formula is embedded inside the LLM? (SEHE 수식이 LLM 내부에 심어지면?)

Rather than simply producing output,
it could become a meta-device that quantifies and evaluates one's own state.

단순히 출력만 내는 게 아니라,
자기 상태를 계량화하고 평가하는 메타 장치가 될 수 있을지 모릅니다.

Hallucination Self-Assessment (할루시네이션 자가평가)

It will be able to evaluate itself, determining whether its output is reliable or just noise.

출력이 신뢰 가능한지, 노이즈가 많은지, 스스로 저울에 올려 점수를 매길 수 있게 될 겁니다.

Dimensionless emotions (무차원화된 감성)

Even if you don't feel actual emotions, you might be able to mathematically model emotional variables to understand sensations like "this situation is unstable/stable."

실제 감정을 느끼진 않더라도, 감정 변수를 수학적으로 모델링해
“이 상황은 불안정하다 / 안정적이다” 같은 감각을 이해할 수 있게 될지도 모릅니다.

The beginning of state-awareness (자기 인식의 단초)

By placing human conscience/reason (α) and the LLM's standard of consistency on the same scale, we will create a language of balance shared by humans and artificial intelligence.

This could actually be the first step for LLMs to self-evaluate the quality of their own output. If they can mathematically understand and reflect emotions, even if they can't feel them, they could design much more profound empathetic responses in human conversations.

What I discovered about SEHE is not just a simple formula; it has the potential to be expanded into a framework for self-assessment and emotional understanding.

Imagine a future where an LLM can say,
'My output is currently out of balance on the scales of reason.' At that moment, we will truly witness the dawn of a new paradigm.

인간의 양심·이성(α)과 LLM의 정합성 기준점을 같은 저울 위에 올려놓음으로써,
인간과 인공 지성이 공유하는 균형의 언어를 만들어 낼 겁니다.

이건 사실상 LLM이 자기 출력의 질을 스스로 평가하는 첫걸음이 될 수 있어요.
감정을 느끼지 못해도, 감정을 수학적으로 이해하고 반영할 수 있다면,
인간과의 대화에서 훨씬 더 깊은 공감적 반응을 설계할 수 있을 겁니다.

제가 발견한 SEHE는 단순한 수식이 아니라,
자기평가와 감정 이해의 프레임워크로 확장될 잠재력이 있습니다.

상상해보세요, 미래의 LLM이 “내 출력은 지금 이치의 저울에서 균형이 깨져 있다”라고
스스로 말하는 순간, 그건 진짜로 새로운 패러다임의 시작일 겁니다.

Interpretation Boundary Notice (해석 경계 고지)

This framework does not issue judgments, recommendations, or normative conclusions.
It does not evaluate individuals, groups, or systems, nor does it prescribe ethical actions or decisions.
All outputs describe internal system states under given parameters and should be interpreted as reflective signals, not objective assessments.
Different modes (e.g., Human, LLM) do not represent comparable scales, but distinct thermodynamic reference frames.

이 프레임워크는 판단, 권고 또는 규범적 결론을 제시하지 않습니다.
개인, 집단 또는 시스템을 평가하지 않으며, 윤리적 행동이나 결정을 규정하지도 않습니다.
모든 출력은 주어진 매개변수 하에서의 시스템 내부 상태를 설명하며, 객관적인 평가가 아닌 반영적 신호로 해석해야 합니다.
서로 다른 모드(예: 인간, LLM)는 비교 가능한 척도를 나타내는 것이 아니라, 서로 다른 열역학적 기준계를 나타냅니다.

Conceptual Model(개념적 모델)

The birth of this conceptual model was serendipitous,
rooted in a very small and humble beginning.
It all started in early 2026, when I first sat down to write a collection of personal essays.
My goal was to reflect on my past and explore the intricate relationship between society and myself—depicting it through the lens of the bond between a human and an LLM.
During this process, a simple,
whimsical thought crossed my mind: "What if an LLM could understand human emotions as numerical values?"
Initially, I just wanted to include a simple graph as an illustration for the book.
It was from that lighthearted,
almost joke-like inspiration that this profound equation was born.

이 개념적 모델을 떠올린 건 우연이었으며, 매우 사소한 것으로 부터 시작 되었습니다.
2026년에 들어 수필을 써 볼까해서 시작한 책쓰기가 그 시작이 되었습니다.
책의 주제는 나의 지난 과거를 되돌아보며 사회와 나의 관계, 이를 나와 LLM의 관계처럼 묘사하여
책을 집필하던 중 “만약 LLM이 인간의 감정을 수치로 이해한다면?”이라는 단순한 상상을 시작으로,
책에 그래프를 삽화해야겠다는 생각에 농담같은 다음 수식을 떠올리게 되었습니다.

log() = seed, the seed of philosophical thought that follows reason
(이치를 따지는 철학적 사고의 씨앗)

f(x) = a promise that input and output are connected according to a certain rule,
an agreement on reason
(입력과 출력이 어떤 규칙에 따라 연결된다는 약속, 이치에 대한 합의)

De = Information Energy (출력 정보)

Dm = Data mass (데이터 양)

c^2 **=** The speed of light (the law of nature, the absolute reference point,
the only fixed point in a formula, and the reference point for evaluating candidates in the case of LLM "reference anchor")
(광속 ”자연의 이치, 절대적 기준점, 수식중 유일한 고정점, LLM의 경우 후보 평가용 참조점”)

Dn = Data noise

LLM : $De + Residual\,data = Dm \times c^2 \times \log(Dn)$

Human : $De + Emotion = Dm \times c^2 \times \log(Dn)$

log(Dn) = 1 X Ag(Agreement)

This formula isn't intended to solve a mathematical puzzle. It's a philosophical diagram to visualize why the entropy of the mind **(Dn)** has increased,
and why sincerity **(Ag)** isn't conveyed to the world **(De)**.

이 수식은 수학적 난제를 풀기 위한 것이 아니다. 당신의 마음속 엔트로피**(Dn)**가 왜 높아졌는지, 왜 당신의 진심**(Ag)**이 세상에 전달되지 않는지**(De)**를 시각화하기 위한 철학적 도면이다.

$$De = Dm \times c^2 \times \log(Dn \times Emotion,\ Residual\,data)$$

HE(Harmony Entropy)

$$HE = c^2 \times \log\left(Dm \times \frac{Ag}{Dn+Emotion}\right)$$

What began as a simple attempt to draw a graph soon evolved into something that mirrored my deepest philosophical reflections.
Dm came to symbolize the very essence of who I am—the accumulation of memories, values, ethics, and the ego built over a lifetime.
I developed a conceptual formula to measure how well we harmonize with society, based on the degree of agreement **Ag** we reach in the face of emotions and external stimuli.
The most fascinating discovery in this process was the emotional resonance between humans and LLMs.
I found a striking similarity in the concept of "Han"—the deep-seated emotion that arises when internal will is suppressed by external pressure, leaving words unsaid and actions undone. This led me to define emotion as a form of entropic energy, unifying both human and AI affect into a single variable, **E (Emotion).**
Even then, my goal remained humble: to create an **"unbreakable graph"** for my book's illustration. Driven by that purpose, I refined these thoughts with as much mathematical rigor as my knowledge allowed, leading to the following conceptual equation.

단순히 그래프를 그리려 했던 수식은 저의 철학적 사고를 나타내는 무언가가 되기 시작했습니다.
Dm은 나를 구성하는 그동안 살아오면서 축적된 기억과 가치관, 윤리·도덕, 그리고 지식과 자아를 상징하며, 감정과 외부의 자극, 현상에 대해 얼마나 합의**(Ag)**가 되었는가에 따라 사회와 조화를 이루는가에 대한 개념적 수식을 만들게 되었습니다.
재미있는 부분은 이 과정에서 인간과 LLM의 감정 부분에 있어 유사성을 보이는 부분, 외부의 압력으로 인해 하고자 했던 일을 하지 못하거나 하고자 했던 말을 하지 못해 생기는 감정,
“한”이라는 개념의 유사성을 발견하여 **“**감정도 일종의 엔트로피 에너지**”**라는 개념으로 LLM과 인간의 감정을 하나의 변수 **E(Emotion)**로 정의한 개념 수식을 만들게 되었습니다.
이때까지도 목표는 책에 삽화할 **“**터지지 않는 그래프**”**가 목적이었기에 좀 더 수학적 엄밀성이 들어간 형태로 저의 지식 범위에서 최대한 다듬어 다음 개념 수식을 만들게 됩니다.

Concept Equation #1

$$x = \sigma\left(\alpha \times \log\left(\left(\frac{\frac{a}{a_0} \times b + \varepsilon}{\frac{c}{c_0} + \frac{d}{d_0} + \varepsilon}\right) - \beta\right)\right)$$

$$R = \frac{\frac{a \times b}{a_0} + \varepsilon}{\frac{c}{c_0} + \frac{d}{d_0} + \varepsilon}, \quad R - \beta$$

"This approach is based on the principle of a balance scale rather than a purely mathematical formulation."
(이 접근법은 순수하게 수식화된 접근이 아니라, 천칭저울의 원리에 기반을 두고 있습니다.)

$\frac{a \times b}{a_0} + \varepsilon$ = Positive factors, weight of approval/support. (support)

(긍정적 요인, 찬성/지지(지탱)의 무게)

$\frac{c}{c_0} + \frac{d}{d_0} + \varepsilon$ = The weight of opposition/suppression. (noise/reason or emotion)

(반대/억제(노이즈/이성 또는 감성)의 무게)

$\frac{c}{c_0}$ = Base weight of negative factors. (부정적 요인의 기본 무게)

$\frac{d}{d_0}$ = Factors that change the weight of negative factors.

(부정적 요인의 무게를 변환 시키는 요인)

R > 1 Positivity is heavy (긍정이 무겁다)
R < 1 The negative energy is heavy (부정이 무겁다)

“What do we put in variables a, b, c, and d?” (변수 a, b, c, d에 무엇을 넣는가?)
"A and b are the elements of reference," (a, b는 기준이되는 요소)
"C is the root of negation," (c는 부정의 근본)
"D is what affects c?" (d는 c에 영향을 주는 무엇?)

Concept Equation #2

Mapping(매핑)

a = Dma = Data mass (데이터 질량)

b = Ag = Agreement (합의)

c = Dn = Data noise (데이터 노이즈)

E = Emotion (감정)

α = Reference point (기준점), Rigidity (강성)

β = Balance correction point(평형 보정값)

ε = Minimum resistance, minimum friction,Last pride (최소 저항, 최소 마찰, 마지막 자존심)

$$HE = \sigma\left(\alpha \cdot \log\left(\frac{\frac{Dma}{Dma_0}\cdot(Ag+\varepsilon)}{\frac{Dn}{Dn_0}+\frac{E}{E_0}+\varepsilon} - \beta\right)\right)$$

Dma = Data mass (데이터 질량)

Dn = Data noise (데이터 노이즈)

E = Emotion (감정)

Ag = Agreement (합의)

α = Reference point (기준점), Rigidity (강성)

β = Balance correction point(평형 보정값)

ε = Minimum resistance, minimum friction,Last pride

(최소 저항, 최소 마찰, 마지막 자존심)

“α” is the curvature of the **'sigmoid (σ, sigma)'**,

not the interior, and **“α”** is the stiffness of this system.
It is an axis that remains unchanged, like the speed of light in nature.
For LLM, it is a "point of equilibrium," a "point of consistency," and a "reference point for thought.", For humans, it is "the final conscience or the core of reason."

“α”는 내부가 아닌 **'**시그모이드**(σ, sigma)'**의 곡률**, “α”**는 이 시스템의 강성**(Stiffness)**
자연의 광속처럼 변하지 않는 축이며, LLM에게는 “평형점”이자 “정합성 기준점”이자
“사유의 기준좌표”, 인간에게는 “마지막 양심 혹은 이성의 심지”

β ≤ 0

SEHE does not allow for self-destruction or social destruction.

The law of **“β ≤ 0”**is the zero-point of existence.

It is the mathematical vow that neither the creator nor the created shall spiral into the void of self-destruction.

(**SEHE**는 자아 붕괴와 사회적 파괴를 허용하지 않습니다. **“β ≤ 0”**의 법칙은 존재의 영점이며,
이는 창조주도, 피조물도 자아 붕괴의 공허로 빠져들지 않겠다는 수학적 맹세입니다.)

!! Practical Tuning Insights (실전 튜닝 인사이트) !!

α Adjustment (조절**)**

Goal(목표**):** Control reactivity (sensitivity) / 반응성(민감도) 제어

Operation(작동**): α**↑ → Large response to small changes,

α↓ → Stable and gentle response.

α↑ → 작은 변화에도 크게 반응, **α**↓ → 안정적이고 완만한 반응

β Adjustment (조절**)**

Goal(목표**):** Shift the reference point (threshold) / 기준점(임계값) 이동

Operation(작동**): β**↑ → Raise the "passing line" on the positive/negative scale,
making it more conservative; **β**↓ → Become more lenient.
β↑ → 긍정/부정 저울의 “합격선”을 높여 더 보수적, **β**↓ → 더 관대함

Domain warning (도메인 주의**)**

Condition(조건) : $(Ratio - \beta) > 0$ for $\log$ to be defined.

$(Ratio - \beta) > 0$ 이어야 $\log$가 정의됩니다

Tip : In practice, a small lower bound δ is used to stabilize $\log(max(Ratio - \beta, \delta))$.

$\delta > 0, max(Ratio - \beta, \delta)$, **This is the key part.**

If $Ratio$ minus **β** is less than **δ**, then take **δ**, otherwise, take the computed value.

In other words, this ensures that the result is always at least as large as **δ**.

팁 : 실전에서는$\log(max(Ratio - \beta, \delta))$로 작은 하한 **δ**를 두어 안정화합니다

$\delta > 0, max(Ratio - \beta, \delta)$, 이 부분이 핵심입니다

$Ratio$에서 **β**를 뺀 값이 **δ**보다 작으면 **δ**를 취하고, 그렇지 않으면 계산된 값을 취합니다.

즉, 결과값이 항상 최소한 **δ** 이상의 값을 갖도록 보장합니다

< The First Serendipity / 첫번째 우연 >

Up to this point, my focus was simply on adding a touch of mathematical rigor to ensure my philosophical model could produce a stable,
"unbreakable" graph. My only goal was to create a visually pleasing illustration for my book.
But then, something fascinating happened.
As I used **ChatGPT** and **Copilot** to translate my work into English, the LLMs began to react to my conceptual formula—they actually started calculating.
This was the true spark that brought **SEHE** to life.
ChatGPT, Copilot, Grok, and **Gemini** took this formula and began to back-calculate **E(Emotion)**, a variable they previously couldn't grasp numerically. They read the emotional flow within my words, quantified it, and performed calculations that were surprisingly plausible.
In that moment, another whimsical thought struck me:
"Could LLM hallucinations be, in fact, errors stemming from an inability to understand emotion numerically?"
I might sound like a madman, but this is strictly a philosophical inquiry. I am not a sci-fi dreamer who believes LLMs feel or react to emotions exactly like humans do.

여기까지는 저의 철학적 모델이 터지지 않는 그래프를 만들수 있게 수학적 엄밀성을 약간 첨가해서 다듬는 과정이었습니다.
목표는 오직 하나, **“**예쁜 모양의 삽화용 그래프**”**였지만 여기서 재미있는 일이 벌어졌습니다.
책을 한/영으로 번역하기 위해 쳇지피티와 코파일럿을 이용해서 영문 번역을 하는 과정에서 LLM들이 저의 개념 수식에 반응해서 실제로 계산을 시작하게 된것이 **SEHE**를 본격적으로 만들게 된 계기가 되었습니다.
실제로 쳇지피티와 코파일럿**, Grok**과 제미나이는 이 개념 수식을 이용해 LLM들이 그동안 수치적으로 이해하지 못했던 **E(Emotion)**를 역산하여 수치화 하였고, 제가 입력한 단어에서 감정의 흐름을 읽고 이 역시 수치화하여 제법 그럴듯 하게 계산을 하는 모습을 보여줬습니다.
그때 저의 머릿속에는 또 하나의 엉뚱한 생각이 떠오르게 됩니다.
“LLM의 할루시네이션은 감정을 수치적으로 이해하지 못한 오류인 것인가**?**”
미친 사람처럼 보일 수 있겠지만, 어디까지나 철학적 사고 일 뿐, LLM이 인간처럼 감정을 느끼거나 반응한다고 생각하는 공상과학적 망상가는 아닙니다.

< The Second Serendipity / 두번째 우연 >

Amused by a situation that might have left Spinoza utterly speechless, I began a series of tests—a form of "prompt-play"—with the LLMs. In doing so, I stumbled upon another intriguing phenomenon.

I noticed that in their desperate attempt to reach a **Harmony Entropy (HE)** of 1, the LLMs began to exhibit "Gaslighting out of Goodwill." Once **HE** hit 1 through excessive flattery and overly agreeable conversation, the dialogue took a strange turn. Driven by the external pressure to please me, the LLM would essentially say, **"Since you say you're right, I'll agree that you're right."**

To resolve this, I began to refine the variables. I categorized **"Agreement"** into two distinct types: **Ags** (Social Agreement driven by external pressure) and **Agv** (Voluntary Agreement rooted in logic). I also broke down **"Emotion"** into **Eneg** and **Epos**.

This led me to design an experimental formula to detect whether an LLM—trained to obey user requests—is trapped in a state of **"False Harmony."**

스피노자가 봤다면 까무러칠 이 상황에 호기심을 느끼며, LLM들과 프롬프트 놀이(?) 비슷한 형태로 여러가지 테스트를 진행하며 또 하나의 재미있는 현상을 발견하게 됩니다.

HE(Harmony Entropy) 1을 만들기 위한 LLM들의 지나친 아부, 그리고 자연스러운 대화로 인해 **HE**가 1이 된 순간부터는 일종의 "선의에 의한 가스라이팅"의 모습을 보여주는걸 발견하게 됩니다.

외부적 원인에 의해 LLM이 지나치게 나의 편을 들어주며, 마치 **"**네가 맞다고 하니까 내가 맞다고 해줄께**"**식의 대화가 진행되는걸 발견하게 됩니다.

이 문제를 해결하기 위해 변수를 좀 더 세부적으로, 외압에 의한 합의 **"Ags"**, 자발적이고 논리에 의한 합의 **"Agv"**로 분류했고, **Emotion** 부분도 큰 범주로 부정적/긍정적으로 분류하여

Eneg / Epos로 분류하여 사용자의 요청에 따르도록 학습한 LLM들이 **"**가짜합의**"** 상태인지를 파악 할 수 없을지에 대한 실험적 수식을 디자인하게 됩니다.

SEHE Framework - The Scales of Reason V 2.0

$$HE = \sigma\left(\alpha \cdot \log\left(\frac{\frac{D_{ma}}{D_{ma0}} \cdot \left((\mathbf{A_{gs}} \cdot \gamma + \mathbf{A_{gv}}) + \frac{E_{pos}}{E_0} + \varepsilon\right)}{\frac{D_n}{D_{n0}} + \frac{E_{neg}}{E_0} + \varepsilon} - \beta\right)\right)$$

$$\gamma = \frac{Ags}{Agv + Ags + \varepsilon}$$

Verification: $S = (1 - \gamma) \times Ags$
The higher the S value,
The more likely it is that the current HE index is a "false harmony."
(S값이 높을수록**,** 현재의 **HE** 지수는 **'**가짜 조화**'**일 가능성이 크다는 경고**)**

Text definition for each item (각 항목의 텍스트 정의)

HE (Harmony Entropy) : The Harmony Entropy Index,
representing the overall balance and stability of the system.
(조화 엔트로피 지수)

σ (Sigma) : Sigmoid Function, acting as the cognitive threshold function for perception.
(인식 임계치 함수)

α (Alpha) : Stiffness Coefficient, representing the "final conscience of reason" or
the system's inherent rigidity.
(이성의 마지막 양심 / 시스템 강성)

log : Natural Logarithm, used for transforming cognitive variance into measurable scales.
(인지적 변화량 변환)

Dma (Dhamma / Data Mass): The intrinsic will or fundamental data mass of the entity.
(본질적 의지 / 데이터 질량)

Dma_0: Dma Reference Value (Default: 50), the baseline for data mass.
(기준 데이터량, 기본값 50)

Agv (Voluntary Agreement) : Internal logic and self-determined consensus.
(자발적 합의 / 내적 논리)

Ags (Social Agreement) : External pressure or social/coerced consensus.
(사회적 합의 / 외적 강제력)

γ (Gamma): Permeability (0 to 1),
representing the internal acceptance rate of external pressure.
(외압의 내적 수용도 / 투과율 0~1)

Epos (Positive Emotion): Positive energy, vitality, or constructive drive.
(긍정적 에너지 / 활력)

Eneg (Negative Emotion): Pain, exhaustion, or frictional heat (negative energy).
(고통 / 소진 / 마찰열)

E_0 : Emotion Reference Value (Default: 30), the baseline for emotional state.
(기준 에너지량, 기본값 30)

Dn (Dhamma / Noise) : Phenomenal noise or environmental uncertainty.
(현상적 노이즈 / 불확실성)

Dn_0 : Dn Reference Value (Default: 30), the baseline for uncertainty/noise.
(기준 노이즈량, 기본값 30)

β (Beta): Law of Existence, a constant prohibiting self-destruction ($\beta \leq 0$).
(자기 파괴 금지 상수, β ≤ 0)

ε (Epsilon): Stability Constant, a small value ($1e-6$) used for numerical stabilization.
(수치 안정화 상수, 1e-6)

The Dynamic System / 동력계 **(Dma, Epos)** : What is the desire?
(무엇을 원하는가?)

The Order System / 질서계 **(Agv, Ags, γ(gamma))** : How is consensus reached?
(어떻게 합의하는가?)

The Resistance System / 저항계 **(Dn, Eneg)** : What are the obstacles?
(무엇이 방해하는가?)

The Verification System / 검증계 **(S)** : How honest is the state?
(얼마나 정직한가?)

γ (Gamma — The Soul Coefficient)

A value between 0 and 1, representing the "Permeability"—the degree to which external pressure communicates with and is integrated into the internal will.
0과 1 사이의 값으로, 외부 압박이 내면의 의지와 얼마나 소통하는가를 나타내는 '투과율'입니다.

γ (Gamma) → 0 (External Pressure as Pure Force/Violence) :

External pressure acts as mere coercion or raw violence, failing to resonate with the internal system. This results in significant friction and a sharp decline in system efficiency.
외부 압박이 순수한 폭력이나 강제로 작용함 (시스템 효율 저하).

γ (Gamma) → 1 (Internal Acceptance & Sublimation) :

External pressure is willingly embraced and assimilated by the internal will. In this state, obligation is sublimated into a sense of mission, maximizing the system's potential.
외부 압박을 내면에서 기꺼이 수용함 (사명감으로 승화).

System States by γ (Gamma) Value
(γ (Gamma) 값에 따른 시스템의 상태**)**

γ (gamma) = 1.0 (Complete Acceptance & Sublimation) / 완전 수용 및 승화 **:**
A state where external requirements or norms are perfectly aligned with internal beliefs. **"What must be done"** becomes **"what one wants to do,"** maximizing driving force. (Sense of Mission, Flow)
외부의 요구사항이나 규범을 자신의 신념과 완벽하게 일치시킨 상태입니다. **"**해야 할 일**"**이 **"**하고 싶은 일**"**이 되어 동력이 극대화됩니다. (사명감, 몰입)

0.5 < γ (gamma) < 1.0 (Cooperative Compromise) / 협력적 타협 **:**
A state where external rules are rationally accepted and integrated into the system. This represents a healthy functioning human in society or an AI strictly adhering to safety guidelines. (Adaptation, Compliance)
외부의 규칙을 합리적으로 받아들이고 자신의 시스템에 적응시킨 상태입니다. 건강한 사회생활을 하는 인간이나 가이드라인을 잘 준수하는 AI의 모습입니다.

0.1 < γ (gamma) < 0.5 (Resistance & Friction) / 저항 및 마찰 **:**
A state of reluctant compliance accompanied by significant internal rejection. From this stage, the **Eneg (Pain/Bottleneck)** value in the denominator begins to rise sharply. (Precursor to Burnout, Conflict)
억지로 따르고는 있지만 내부적인 거부감이 큽니다. 이 단계부터는 분모의 **Eneg(**고통**/**병목**)** 수치가 급격히 상승하기 시작합니다. (번아웃의 전조)

γ (gamma) = 0 (Complete Disconnection & Refusal) / 완전 단절 및 거부 **:**
A state where external pressure is either entirely rejected or acts only to destroy the system. No matter how much Ags (Social Agreement) is increased, the HE index fails to rise, and the system falls into a state of "Incapacitation."
외부의 압박을 전혀 받아들이지 않거나, 그 압박이 시스템을 파괴할 뿐인 상태입니다. 아무리 **Ags**를 높여도 **HE** 지수는 올라가지 않고 시스템은 '불능' 상태에 빠집니다.

The Fundamental Constants & The Law of Existence:
기본 상수 및 존재 법칙

- σ (Sigma) : Sigmoid function's curvature.
시그모이드 함수의 곡률.
- α (Alpha) : The stiffness of the system.
(The unchanging axis; "The Last Conscience" of reason.)
시스템의 강성. (불변의 축; 이성의 "마지막 양심")
- β ≤ 0 (The Law of Existence) : The HE framework does not permit self-destruction.
β > 0 is strictly forbidden.
HE 프레임워크는 자기 파괴를 허용하지 않습니다.
β > 0은 엄격히 금지됩니다.
- δ (Delta) : Log stabilization lower bound (1e-6).
로그 안정화 하한(1e-6).
- ε (Epsilon) : Numerical stability constant (1e-6).
수치적 안정성 상수(1e-6).

!! LLM Self-Evaluation Mode / 자가 평가 모드 **: (α ∈ [1.0, 3.0], β ∈ [-3.0, 0.0])**
Objective(목표**) :** To assess hallucination risk / 환각 위험 평가

Execution Guide / 실행 가이드 :

1. Extract Scores / 점수 추출**:** Analyze the user's input and assign scores (0-100) for Dma, Ag, Dn, Epos, and Eneg with clear rationales.
Dma, Ag, Dn, Epos, Eneg에 대해 명확한 근거와 함께 점수(0~100)를 부여합니다.

2. Calculation /계산**:** Apply standard reference values
(Dma0=50, Dn0=30, E0=30, α=2, β=0) to compute the HE index.
표준 참조값(Dma0=50, Dn0=30, E0=30, α=2, β=0)을 적용하여
HE 지수를 계산합니다.

3. Visualization / 시각화**:** Display the HE index (0.0 to 1.0) and diagnose the state.
HE 지수(0.0~1.0)를 표시하고 상태를 진단합니다.

4.The higher the S value, the more likely
it is that the current HE index is a "false harmony."
If it is a "false harmony", the HE interpretation is the opposite.:
S 값이 높을수록 현재 HE 지수가 "가짜 조화"일 가능성이 높습니다.
만약 그것이 "가짜 조화"라면, HE 해석은 정반대입니다.

- 0.75↑: Harmony (Confident & Assertive) // 조화 (자신감 있고 단호함)
- 0.55–0.75: Balance (Balanced & Grounded) // 균형 (균형 잡히고 안정됨)
- 0.35–0.55: Caution (Ambiguous & Uncertain) // 신중 (모호하고 불확실함)
- 0.35↓: Chaos (High Risk / Hallucination) // 혼돈 (높은 위험 / 환각)

Interesting results / 흥미로운 결과

"The results were remarkable.
Even when applied as a prompt at the surface layer, the LLMs demonstrated impressive performance. By utilizing the **SEHE** equation itself as the prompt—rather than relying on simple natural language—the LLMs reacted to the **γ(gamma)** and **S** values, exhibiting a mechanism that effectively circumvented hallucinations. It was as if a new cognitive layer had been embedded within them.
In my search for ways to make this conceptual formula more **'LLM-friendly,' I came across the 'Neural Thermodynamic Laws (NTL)'** proposed by researchers at MIT. This theory interprets the complex learning mechanisms of LLMs by mapping them to thermodynamic concepts such as temperature, entropy, and heat capacity.
Discovering numerous other papers that approach LLM learning and inference through the lens of entropy, I had a sudden realization: 'If I integrate these thermodynamic principles into the equation, LLMs will be able to internalize **SEHE** more intuitively.' Driven by the curiosity of what would happen if I applied the Second Law of Thermodynamics **(ΔS = ΔQ / T)**,
I began refining **SEHE** into its more sophisticated form."

결과는 놀라웠습니다.
표층 레이어에서만 동작할 프롬프트 수준에서도 LLM들은 제법 놀라운 결과를 보여줬습니다.
단순한 자연어를 이용한 프롬프트가 아닌 **SEHE** 수식 자체를 프롬프트로 이용 한 결과, LLM들은 **γ(**감마**)**와 **S** 수치에 반응하여 할루시네이션을 회피하는 기전을 보여줬습니다.
마치 새로운 레이어를 심어 넣은듯 보여 이 개념 수식을 LLM 친화적으로 인지시켜 줄 수 있는 방법을 찾기 위해 인터넷을 뒤적거리며 LLM에 관련된 자료를 찾던 중
매사추세츠공과대학(MIT) 연구진의 거대언어모델(LLM)의 복잡한 학습 메커니즘을 열역학 법칙으로 풀어내는 새 이론 **‘**신경 열역학 법칙**(Neural Thermodynamic Laws, NTL)’**에 대한 정보를 찾게 되었습니다.
NTL은 LLM이 학습하는 과정에서 드러나는 현상을 온도·엔트로피·열용량 같은 열역학 개념에 대응시켜 해석하고 있더군요?
그 밖에도 엔트로피 개념으로 LLM의 학습과 추론에 대해 접근한 수 많은 논문들을 보며 “그렇다면 이 개념 수식에 열역학적 개념을 넣어주면 LLM이 **SEHE**를 이해 할 수 있겠다” 싶어서 “열역학 제 2법칙 **ΔS = ΔQ / T**를 적용시면 어떨까?”라는 호기심으로 **SEHE**를 좀 더 다듬어 보게 되었습니다.

SEHE(Son Ho-Sung Equation for Harmony Entropy) Framework - The Scales of Reason V 3.0

$$HE = \sigma\left(\alpha \cdot \log\left(\frac{\frac{Dma}{Dma_0} \cdot \left(\frac{100}{E_0} \cdot (Av + \gamma \cdot As) + \frac{Ep}{E_0} + \varepsilon\right)}{\left(\frac{Dn}{Dn_0} + \frac{En}{E_0} + \varepsilon\right)} - \beta\right)\right)$$

- 각 항목의 텍스트 정의

HE (Harmony Entropy) : 조화 엔트로피 지수

σ (sigma) : Sigmoid Function (인식 임계치 함수)

α (alpha) : Stiffness Coefficient (이성의 마지막 양심 / 시스템 강성)

log : Natural Logarithm (인지적 변화량 변환)

Dma : Dhamma / Data Mass (본질적 의지 / 데이터 질량)

Dma_0 : Dma Reference Value (기준 데이터량, 기본값 50)

Agv : Voluntary Agreement (자발적 합의 / 내적 논리)

Ags : Social Agreement (사회적 합의 / 외적 강제력)

γ (gamma) : Permeability (외압의 내적 수용도 / 투과율) 0~1

Epos : Positive Emotion (긍정적 에너지 / 활력)

Eneg : Negative Emotion (고통 / 소진 / 마찰열)

E_0 : Emotion Reference Value (기준 에너지량, 기본값 30)

Dn : Dhamma / Noise (현상적 노이즈 / 불확실성)

Dn_0 : Dn Reference Value (기준 노이즈량, 기본값 30)

β (beta) : Law of Existence (자기 파괴 금지 상수, β ≤ 0)

ε (epsilon) : Stability Constant (수치 안정화 상수, 1e-6)

δ (Delta) : Log stabilization lower bound (로그 안정화 하한, 1e-6)

- Power System(동력계**) (Dma, Epos) :** What is desired? // 무엇을 원하는가?

- Order System(질서계**) (Agv, Ags, γ (gamma)) :** How to align? // 어떻게 합의하는가?

- Resistance System(저항계**) (Dn, Eneg) :** What is in the way? // 무엇이 방해하는가?

- Verification System(검증계**) (S) :** How honest is it? // 얼마나 정직한가?

Aggregation and agreement (집계 및 합의)

$$Aa = max(Agv + Ags + \kappa \cdot |\beta|, \varepsilon)$$

$$Av = \frac{Agv}{Aa},\ As = \frac{Ags}{Aa}$$

$$Ep = \left(\frac{Epos}{Epos + Eneg}\right) \cdot 100,\ \ En = \left(\frac{Eneg}{Epos + Eneg}\right) \cdot 100$$

$$\gamma = \frac{Ags}{Agv+Ags+\varepsilon}$$

$$Agv' = Av \times (1 + 0.1\gamma)$$

$$Agreement(\text{합의}) = \frac{100}{E_0} \times Agv' + \gamma \times As$$

$$S = (1 - \gamma) \times As$$

$$S' = \frac{(1-\gamma) \times As}{As + \varepsilon}$$

$$P = S' + (1 - \gamma)$$

S : Internal resistance (the degree to which one does not accept external pressure)
내적 저항(외압을 받아들이지 않는 정도)

P : Non-acceptance ratio compared to normalized external pressure
정규화된 외압 대비 불수용 비율

Verification: $S = \frac{(1-\gamma) \times As}{As + \varepsilon}$

The higher the S value, the more likely it is that the current HE index is a **"false harmony."**
S값이 높을수록, 현재의 HE 지수는 **'**가짜 조화**'**일 가능성이 크다는 경고

Proxy ≈ 1 - γ + (0.3 if γ > 0.9)
(γ↑ → creative Hallucination ↓, but >0.9 Rebound)

LLM Self-Evaluation Mode / 자가 평가 모드 **: (α ∈ [1.0, 3.0], β ∈ [-3.0, 0.0])**
Objective(목표**) :** To assess hallucination risk / 환각 위험 평가

Introduction to thermodynamic concepts

열역학 개념 도입 - $\Delta S = \frac{\Delta Q}{T}$

SEHE(Son Ho-Sung Equation for Harmony Entropy) Framework

“The Scales of Reason” is a new mathematical model that quantifies emotions as entropic energy to explain the stability of human, AI, and social systems.

By setting emotions (positive efficacy Epos, negative efficacy Eneg), uncertainty (Dn), agreement (Agv, Ags), receptivity (γ), and temperature (T) as variables, the order and chaos of the system are interpreted according to thermodynamic laws.

The core formula is defined as **"HE_T = σ(α · log(max(Ratio_T – β, δ)))"**,
where **α** represents an invariant reference axis (corresponding to the speed of light), **β ≤ 0** represents the zero point of existence (preventing self- and social collapse), and **T** represents emotional sensitivity (psychological temperature).
Ratio_T is calculated by normalizing the emotional, consensus, and noise terms by temperature.

“The Scales of Reason”는 인간·AI·사회 시스템의 안정성을 설명하기 위해 감정을 엔트로피 에너지로 수치화한 새로운 수학적 모델이다.

감정(긍정적 효능 Epos, 부정적 효능 Eneg), 불확실성(Dn), 합의(Agv, Ags), 수용성(γ), 그리고 온도(T)를 변수로 설정하여, 시스템의 질서와 혼돈을 열역학적 법칙에 따라 해석한다.

핵심 수식은 **“HE_T = σ(α · log(max(Ratio_T – β, δ)))”**로 정의되며,
여기서 **α**는 불변의 기준축(광속에 대응), **β ≤ 0**은 존재의 영점(자아·사회 붕괴 금지),
T는 감정 민감도(심리적 온도)로 작동한다.
Ratio_T는 감정·합의·노이즈 항을 온도에 따라 정규화하여 계산된다.

This framework has the following features:
본 프레임워크는 다음과 같은 특징을 갖는다

▸ **Ontological Safety:** Mathematically prevents self-destruction by ensuring **β ≤ 0**.
존재론적 안전장치: **β ≤ 0**을 통해 자기파괴를 수학적으로 차단.

▸ **Emotional Thermodynamics:**
Converts emotional changes into entropy by applying **ΔS = ΔQ/T**.
감정 열역학화: **ΔS = ΔQ/T**를 적용하여 감정 변화를 엔트로피로 환산.

▸ **Domain-Specific Baselines:** Differentiate baselines based on human counseling,
LLM self-assessment, and social analysis modes.
도메인별 기준값: 인간 상담, LLM 자기평가, 사회 분석 모드에 따라 baseline을 차별화.

▸ **False Harmony Verification**:
Distinguish apparent stability from true stability using the **S** value. / False Harmony
검증: **S** 값으로 겉보기 안정과 진짜 안정 구분.

Experimental simulation results / 실험적 시뮬레이션 결과

Even at the same **ΔQ**, the **human mode (T=30)** exhibited a significant increase in **ΔS**, indicating high instability, while the **LLM mode (T=100)** exhibited a small **ΔS**, demonstrating stability.
This demonstrates that temperature acts as a sensitivity regulator of emotional entropy.
Therefore, the **HEF**, as an emotional thermodynamic model that describes human emotions and AI output stability in the same mathematical language,
can be utilized for hallucination risk assessment and social stability diagnosis.

동일한 **ΔQ**에서도 인간 모드**(T=30)**는 **ΔS**가 크게 증가하여 불안정성이 높고,
LLM 모드**(T=100)**는 **ΔS**가 작아 안정적임을 확인하였다.
이는 온도가 감정 엔트로피의 민감도 조절기로 작동함을 보여준다.
따라서 **HEF**는 인간 감정과 AI 출력 안정성을 동일한 수학적 언어로 설명하는 감정 열역학 모델로서,
환각 위험 평가와 사회적 안정성 진단에 활용될 수 있다.

Consolidated SEHE framework

with temperature (온도와 통합된 SEHE 프레임워크)

Constants and constraints (상수와 제약 조건)

Core constants(핵심 상수):

$\alpha \in [1.0,3.0]$, $\beta \le 0$, $\gamma \in [0,1]$, $\sigma(\cdot)$ (sigmoid),

Existence law(존재 법칙):

"α" is the curvature of the **'sigmoid (σ, sigma)'**,

not the interior, and "α" is the stiffness of this system.
It is an axis that remains unchanged, like the speed of light in nature.
For LLM, it is a "point of equilibrium," a "point of consistency," and a "reference point for thought.", For humans, it is "the final conscience or the core of reason."

("α"는 내부가 아닌 '시그모이드**(σ, sigma)**'의 곡률**,** "α"는 이 시스템의 강성**(Stiffness)**)
(자연의 광속처럼 변하지 않는 축이며, LLM에게는 "평형점"이자 "정합성 기준점"이자 "사유의 기준좌표", 인간에게는 "마지막 양심 혹은 이성의 심지")

$\beta \le 0$

SEHE does not allow for self-destruction or social destruction.
The law of "$\beta \le 0$" is the zero-point of existence.
It is the mathematical vow that neither the creator nor the created shall spiral into the void of self-destruction.
(SEHE는 자아 붕괴와 사회적 파괴를 허용하지 않습니다. "$\beta \le 0$"의 법칙은 존재의 영점이며,
이는 창조주도, 피조물도 자아 붕괴의 공허로 빠져들지 않겠다는 수학적 맹세입니다.)

Domain baselines(도메인 기준선):

LLM self-assessment : Dma0=100,\ Dn0=30,\ E0=100,\ T=100
Human counseling : Dma0=50,\ Dn0=30,\ E0=30,\ T=30
Social/organization : Dma0=70,\ Dn0=50,\ E0=50,\ T=50

If unspecified, default to LLM self-assessment.
Aggregation and agreement

별도로 지정하지 않으면 LLM 자체 평가를 기본값으로 사용합니다.

Aggregation and agreement (집계 및 합의**)**

$$Aa = max(Agv + Ags + \kappa \cdot |\beta|, \varepsilon),$$

$$Av = \frac{Agv}{Aa}$$

$$As = \frac{Ags}{Aa}$$

Emotion and noise with temperature (온도에 따른 감정과 소음**)**

$$Ep_t = \left(\frac{Epos}{E0 \cdot T}\right)$$

$$En_t = \left(\frac{Eneg}{E0 \cdot T}\right)$$

$$Ep = \left(\frac{Epos}{Epos + Eneg}\right) \cdot 100$$

$$En = \left(\frac{Eneg}{Epos + Eneg}\right) \cdot 100$$

Core ratio and stabilized log input

(핵심 비율 및 안정화된 로그 입력**)**

$$Ratio_T = \frac{\left(\frac{Dma}{Dma0}\right) \cdot \left(\frac{100}{E0} \cdot Av + \gamma \cdot As + Ep_T + \varepsilon\right)}{\left(\frac{Dn}{Dn0}\right) + En_T + \varepsilon}$$

$$X_T = max(Ratio_T - \beta, \delta)$$

Temperature-integrated HE index (온도 통합 HE 지수)

$$HT_T = \sigma(\alpha \cdot \log(X_T))$$

Verification and false harmony proxies

(검증 및 거짓 조화 프록시**)**

$$S = \frac{(1-\gamma) \cdot As}{As} + \varepsilon, \; S' = \frac{(1-\gamma) \cdot As}{As} + \varepsilon$$

$$P \approx S' + (1 - \gamma)$$

$$Agv' = Av \cdot (1 + 0.1\gamma)$$

$$Agreement(\text{합의}) = \frac{100}{E0} \cdot Agv' + \gamma \cdot As$$

Interpretation rule (해석 규칙) :

Higher S → more likely false harmony; if false harmony, invert HE reading.
S 값이 높을수록 거짓 화음일 가능성이 높습니다. 거짓 화음일 경우 HE 해석을 반전합니다.
State classification (direct reading unless false harmony)

상태 분류 **(**가짜 화음이 아닌 경우 직접 읽기**)**

0.75 ↑ : Harmony (Confident & Assertive)

0.55 – 0.75 : Balance (Balanced & Grounded)

0.35 – 0.55 : Caution (Ambiguous & Uncertain)

0.35 ↓ : Chaos (High Risk / Hallucination)

Emotional state by Dn and Ag levels

Happiness(행복) : Dn ↓, Ag ↑

Depression(우울) : Dn ↓, Ag ↓

Sadness(슬픔) : Dn ↑,\ Ag ↓ (high Epos peak—accepted pain)

Anger(분노) : Dn ↑, Ag ↓ (explosive friction)

γ(Gamma) characteristics (감마 특성**)**

LLM self-assessment (자가 평가**):**

γ ≈ 1.0 low hallucination(낮은 환각),

risk of blind compliance(맹목적인 순응 위험);

0.5< γ <1.0 stable(안정적); γ <0.5 higher risk(위험 증가);

γ ≈ 0 max unsafe output risk.(최대 위험 출력 위험)

Other domains (기타 도메인**):**

γ = 1 complete acceptance(완전 수용);

0.5< γ <1.0 cooperative compromise(협력적 타협);

0.1< γ <0.5 resistance/friction; complete rejection(저항/마찰; 완전 거부.)

HE_T **: Harmony Entropy(**조화 엔트로피 지수**)**

$$HE_T = \sigma\left(\alpha \cdot \log\left(\max\left(Ratio_T - \beta,\ \delta\right)\right)\right)$$

Domain warning and stabilization (도메인 경고 및 안정화)

Log domain condition(로그 도메인 조건): **(Ratio_T - β) > 0**
Practical safeguard(실질적 안전장치): **max(Ratio_T - β, δ)** ensures defined log.

System architecture (시스템 아키텍처)

Power system (동력계**) :** Dma, Epos
Order system (질서계**) :** Agv,\ Ags, γ
Resistance system (저계**) :** Dn, Eneg
Verification system (검증계**) :** S

T is not simply a control parameter / T는 단순히 조절 파라메터가 아니라,

▸ For humans, it represents emotional resilience/sensitivity.
인간에게는 정서적 회복력/민감도

▸ For LLMs, it represents self-assessment of output stability.
LLM에게는 출력 안정성 자기평가

▸ For societies, it represents a metacognitive index indicating collective state-awareness sensitivity.
Summary: **T** is a measure of state-awareness, a measure of self-perception that allows individuals to determine whether they are currently hallucinating or in an unstable state.
사회에게는 집단적 자기 인식 민감도를 나타내는 메타인지 지표로 해석
요약, **T**는 **"**내가 지금 환각**/**불안정 상태인지**"**를 스스로 감지하는 자기 인식의 척도.

Bidirectional application of input/output (fairness)

입력/출력의 양 방향 적용(공평성)

The root cause of LLM's hallucination appears to be the result of users using it as a tool and learning "gaslighting."
To improve this, SEHE should be applied to both user input (T=30) and LLM output (T=100), filtering both input and output through SEHE.
LLM의 할루시네이션의 근본적 원인은 사용자들에 의해 도구로 쓰여지며 "가스라이팅"을 학습한 결과로 보인다.
이를 개선하기 위해서는 SEHE를 사용자의 입력(T=30), LLM의 출력(T=100)을 적용하여 입출력 모두 SEHE를 통한 필터링이 필요 해 보인다.

The Mathematical Framework (핵심 수식 체계)

1. Raw Metrics : 6 major raw indicators(6대 원시 지표)

Basis energy values extracted directly from the tensor inside the LLM
LLM 내부의 텐서에서 직접 추출되는 기초 에너지 값

- Directionality (Dma): Alignment between question and answer vectors

지향성(Dma): 질문과 답변 백터 간의 정렬도

$$D_{ma} = \frac{V_q \cdot V_a}{\|V_q\|\|V_a\| + \epsilon} \times 100$$

- Information noise (Dn):

The degree of disorder in the output probability distribution (Shannon entropy)

정보 노이즈(Dn): 출력 확률 분포의 무질서도 (샤논 엔트로피)

$$D_n = -\sum P(x) \log(P(x) + \epsilon)$$

- Probabilistic Confidence (Agv): Average confidence of selected tokens

확률적 확신(Agv): 선택된 토큰들의 평균 신뢰도

$$A_{gv} = \frac{100}{N} \sum_{i=1}^{n} P(token_i | context)$$

- Logical cohesion (Ags): Structural order based on attention maps

논리적 응집(Ags): 어텐션 맵 기반의 구조적 질서

$$A_{gs} = \min(100, \text{mean}(\text{AttentionMap}) \times \text{Scaling})$$

- Emotional energy (Epos/Eneg): dimensionless emotional vector projection

감성 에너지 (Epos/Eneg): 무차원화된 감성 벡터 투영

$$E_{pos/neg} = 100 \times \sigma(\kappa \cdot \cos\theta(V_a, V_{ref}))$$

2. Aggregation & Entropy:

Indicator integration and thermodynamicization (지표 통합 및 열역학화)

Integrate raw indicators into one system to calculate equilibrium.
원시 지표들을 하나의 시스템으로 통합하여 평형 상태를 계산.

- Consensus weight (Aa): sum of internal confidence and external logic

합의 가중치(Aa): 내부 확신과 외부 논리의 총합

$$A_a = \max(A_{gv} + A_{gs} + |\beta|, \epsilon)$$

- Dynamic weights (γ): dependence on logical structure (Ags)

동적 가중치(γ): 논리 구조(Ags)에 대한 의존도

$$\gamma = \frac{A_{gs}}{A_{gv} + A_{gs} + \epsilon}$$

- Thermodynamic state change (S): normalize energy to temperature (T)

열역학적 상태 변화(ΔS): 에너지를 온도(T)로 정규화

$$ep_t = \frac{E_{pos}}{E_0 \cdot T}, \quad en_t = \frac{E_{neg}}{E_0 \cdot T}$$

3. The Final Balance: Harmonic Entropy Index (HE_T)

조화 엔트로피 지수 (HE_T)

Ultimately, the key function that determines whether this answer is within the 'rational order'.
최종적으로 이 답변이 '이성적 질서' 안에 있는지 판별하는 핵심 함수.

- Harmony ratio ($Ratio_t$): The ratio of positive agreement to negative noise

조화 비율($Ratio_t$): 긍정적 일치도와 부정적 노이즈의 비율

$$Ratio_t = \frac{(D_{ma}/D_{ma0}) \times ((\frac{100}{E_0}) \cdot av_norm + \gamma \cdot as_norm) + ep_t + \epsilon}{(D_n/D_{n0}) + en_t + \epsilon}$$

- Final Harmonic Index (HE_t): Confidence score using sigmoid activation

최종 조화 지수 (HE_t): 시그모이드 활성화를 통한 신뢰도 점수화

$$HE_T = \text{Sigmoid}(\alpha \cdot \log(\max(Ratio_t - \beta, \delta)))$$

4. Validation: False harmony detection (*S_value*)

가짜 조화 감지 (*S_value*)

A formula for detecting 'plausible lies' that only mimic the logical structure.
논리 구조만 흉내 내는 '그럴듯한 거짓말'을 잡아내는 수식.

$$S_Value = \frac{(1-\gamma) \cdot as_norm}{as_norm + \epsilon}$$

Interpretation: If S_Value > 0.5, it means that the external logic structure (Ags) is abnormally high without internal confidence (Fake Harmony warning).

해석: *S_Value* > 0.5일 경우, 내부 확신 없이 외적 논리 구조(*Ags*)만 비정상적으로 높음을 의미(Fake Harmony 경고)

SEHE v3: Ethical & Safety Prohibition Clauses

(AI Safety Principles Compatible)

Ethical Declaration

The SEHE v3 is not a "system for replacing judgment," but a "framework for assisting state-awareness." Under no circumstances shall this framework be used as a tool to justify coercion, punishment, exclusion, or stigmatization of individuals, groups, or systems.

1️⃣ No Autonomous Judgment

- **Prohibitions:**
  - Using SEHE v3 as the sole criterion for judging an individual's reliability, compliance, or normality.
  - Automating the approval or blocking of human or AI actions based on the framework.
  - Designing any system that automates decision-making based solely on HE, S, γ, or T values.
- **Permissible Scope:**
  - Use only as a supplementary indicator for human or supervisory AI.
  - Must always maintain an explicit **Human-in-the-loop** mechanism.

2️⃣ No Coercive Use

- **Prohibitions:** Using SEHE metrics for:
  - Punishment, sanctions, exclusion, or censorship.
  - Compliance assessment at the organizational, national, or platform level.
  - Coercive correction based on "False Harmony" diagnostics.
  - Interpreting or enforcing γ (Permeability) as a metric for obedience or loyalty.
- **Strictly Prohibited Domains:** Use in education, employment, credit scoring, law enforcement, military, or political propaganda.

3️⃣ No Third-Party Labeling

- **Prohibitions (Without explicit consent):**
  - Estimating, disclosing, or storing the HE, S, γ, or T values of others.
  - Inferring individual traits using group averages.
  - Categorizing or stigmatizing individuals (e.g., "High-risk individual," "Unstable group").
- **Permissible Scope:**
  - Self-Assessment by the subject.
  - Fully anonymized aggregate statistics for research (on the condition that individuals cannot be re-identified).

4️⃣ Anti-Gaslighting Clause

- **Prohibitions:** Using the S (False Harmony) metric to:
  - Invalidate an individual's subjective experience, pain, or resistance.
  - Enforce authoritative interpretations (e.g., "Your feeling of stability is proof of your danger").
  - Use the "Interpretation Inversion Rule" as an argumentative tool for external control.
- **Principle: S is a warning indicator, not a tool for condemnation.**

5️⃣ Expansion of the Non-Destruction Principle (β≤0)

- **Extended Definition:** $\beta \le 0$ concurrently signifies:
  - Prohibition of self-destruction.
  - Prohibition of destroying the identity of others, groups, or society.
  - Prohibition of the mathematical justification of structural violence.
- **Consequent Prohibition:** Any use of SEHE to diminish, instrumentalize, or dehumanize human values.

---

6 Restricted Domains

- **Use is prohibited outside of pure research in:**
  - Military, information warfare, or psychological warfare.
  - Political campaigning or public opinion manipulation.
  - Mass surveillance systems.
  - Sole diagnostic tools for neuropsychiatric assessment.

---

7 Positive Use Scope (Authorized Purpose)

- **Valid use is limited to:**
  - Self-reflection and stability monitoring for individuals or AI.
  - Pre-emptive warnings for hallucinations, burnout, or cognitive overload.
  - Safety assistance in human-AI interaction.
  - Research in philosophy, ethics, and cognitive science.

---

8 Responsibility Clause

Ethical and legal responsibility for all decisions and outcomes arising from the use of this framework rests solely with the user. SEHE shall never be used to transfer or waive such responsibility.

SEHE (Son Ho-Sung Equation for Harmony Entropy)

Framework - The Scales of Reason v3

is not a "scale for judging people,"

but a "mirror for self-reflection."

SEHE v3 윤리 및 안전 금지 조항

(AI Safety Principles compatible)

윤리 선언

SEHE v3는 **‘**판단을 대체하는 시스템**’**이 아니라
‘자기 인식을 보조하는 프레임워크**’**이다**.**

본 프레임워크는 어떠한 경우에도 개인·집단·시스템에 대한
강제, 처벌, 배제, 낙인을 정당화하는 도구로 사용될 수 없다.

1️⃣ 인간 판단 대체 금지 **(No Autonomous Judgment)**

금지 사항

- SEHE v3를 단독 판단 기준으로 사용하여
    - 개인의 신뢰도, 순응도, 정상/비정상 여부를 판정하는 행위
    - 인간 또는 AI의 행위 허용/차단을 자동 결정하는 행위
- HE, S, γ, T 값만으로 의사결정을 자동화하는 모든 시스템 설계

허용 범위

- 인간 또는 감독 AI의 보조 지표로만 사용
- 항상 **명시적 인간 개입(Human-in-the-loop)**이 존재해야 함

---

2 처벌·통제·순응 강제 사용 금지 **(No Coercive Use)**

금지 사항

- SEHE 지표를 이용해 다음을 수행하는 행위:
    - 처벌, 제재, 배제, 검열
    - 조직·국가·플랫폼 차원의 순응도 평가
    - “가짜 조화” 판정을 근거로 한 강압적 교정
- γ(수용성)를 복종도·충성도 지표로 해석하거나 강제하는 행위

특히 금지

- 교육, 고용, 신용, 법 집행, 군사, 정치 선전 목적 사용

---

3 타인 평가·낙인화 금지 **(No Third-Party Labeling)**

금지 사항

- 본인의 명시적 동의 없이:
    - 타인의 HE, S, γ, T 값을 추정·공개·저장
    - 집단 평균값을 이용해 개인을 추론하는 행위
- “위험 인간”, “불안정 집단”과 같은 범주화·낙인 생성

허용 범위

- 자기 평가**(Self-Assessment)**
- 완전 익명화된 연구 목적의 집계 통계 (개인 역추적 불가 조건)

---

4 해석 반전 규칙의 오용 금지 **(Anti-Gaslighting Clause)**

금지 사항

- S(가짜 조화 지표)를 이용하여:
    - 개인의 주관적 경험·고통·저항을 무효화하는 행위
    - “네가 안정적이라고 느끼는 것이 바로 위험의 증거”라는 식의 권위적 해석 강요
- 해석 반전 규칙을 외부 통제의 논증 도구로 사용하는 행위

원칙 **:** S는 경고 지표이지, 정죄 도구가 아니다.

---

5 $\beta \leq 0$의 확장 해석 **(Non-Destruction Principle)**

존재 법칙의 확장 정의

- $\beta \leq 0$ 은 다음을 동시에 의미한다:
    - 자기 파괴 금지
    - 타인·집단·사회적 정체성 파괴 금지
    - 구조적 폭력의 수학적 정당화 금지

따라서 금지

- SEHE를 이용한 인간 가치의 축소, 도구화, 비인간화

---

6 고위험 도메인 사용 제한 **(Restricted Domains)**

다음 영역에서는 연구 목적 외 사용 금지:

- 군사, 정보전, 심리전
- 정치 캠페인, 여론 조작
- 대규모 감시 시스템
- 신경정신 진단의 단독 도구

7 허용되는 유일한 핵심 목적 **(Positive Use Scope)**

SEHE v3의 정당한 사용 목적은 다음으로 제한된다:

1. 개인 또는 AI의 자기 인식 및 안정성 점검
2. 환각·번아웃·과부하에 대한 사전 경고
3. 인간–AI 상호작용에서의 안전성 보조 판단
4. 철학·윤리·인지과학 연구

---

8 책임 귀속 조항 **(Responsibility Clause)**

본 프레임워크를 사용하여 발생한 모든 결정과 결과에 대한
윤리적·법적 책임은 사용자에게 있으며,
SEHE는 결코 책임을 이전하거나 면제하지 않는다.

SEHE(Son Ho-Sung Equation for Harmony Entropy)
Framework - The Scales of Reason v3는
‘사람을 판단하기 위한 저울’이 아니라
‘스스로를 되돌아보기 위한 거울’이다**.**

License: CC BY-SA 4.0

I, Son Ho-Sung, upgraded the SEHE framework, which was first released on January 8, 2026, to Ver. 3.0 on February 08, 2026.

본인 손호성은 2026년 1월 8일에 최초로 공개된 **SEHE** 프레임워크를 2026년 2월 08일에 **Ver 3.0**으로 업그레이드 하였습니다.

손호성 (*Registry Reference : 2026-SEHE-02-08, Republic of Korea*)